

## Lineární proces [linear process]

Teoretickým základem modelů tzv. **Boxovy-Jenkinsovy metodologie** je **lineární proces**, který je definován jako

$$(1) \quad y_t = \varepsilon_t + \psi_1 \varepsilon_{t-1} + \psi_2 \varepsilon_{t-2} + \dots = \left( 1 + \psi_1 B + \psi_2 B^2 + \psi_3 B^3 + \dots \right) \varepsilon_t = \psi(B) \varepsilon_t,$$

kde  $\varepsilon_t$  je tzv. **bílý šum [white noise]** [= posloupnost nekorelovaných, stejně rozdělených náhodných veličin s nulovou střední hodnotou a konstantním konečným rozptylem  $\sigma^2 > 0$ ] a  $B$  je operátor časového posunu.

Dále se předpokládá, že mocninná řada  $\psi(z)$  proměnné  $z$  konverguje pro  $|z| \leq 1$  (tj. uvnitř a na jednotkovém kruhu v komplexní rovině).

Za tohoto předpokladu lze ukázat, že nekonečné řady náhodných veličin (1) pro jednotlivá  $t$  **konvergují podle kvadratického středu<sup>1</sup>**, přičemž limitní hodnoty  $\hat{y}_t$  tvoří stacionární posloupnost s nulovou střední hodnotou  $E \hat{y}_t = 0$ .

Jiné vyjádření lineárního procesu (1), které je užitečné např. při konstrukci předpovědí, je možné v případě, že tento **proces je invertibilní** a lze ho zapsat jako

$$(2) \quad y_t = \pi_1 y_{t-1} + \pi_2 y_{t-2} + \pi_3 y_{t-3} + \dots + \varepsilon_t \quad \text{neboli}$$

$$(2A) \quad \varepsilon_t = y_t - \pi_1 y_{t-1} - \pi_2 y_{t-2} - \pi_3 y_{t-3} - \dots = \pi(B) \cdot y_t,$$

Přitom **postačující podmínkou invertibility** je předpoklad analogický předpokladu (2), že

(3) mocninná řada  $\pi(z)$  konverguje pro  $|z| \leq 1$ , tj. uvnitř a na jednotkovém kruhu v komplexní rovině.

**Poznámka1** Existuje řada důvodů, proč modely postavené na principu lineárního procesu jsou vhodné pro modelování reality. Necht' pro stacionární proces  $\hat{y}_t$  s nulovou střední hodnotou předpovídáme hodnotu  $\hat{y}_t$  na základě znalosti minulých hodnot  $Y_{t-1} = \hat{y}_{t-1}, y_{t-2}, \dots$ . Optimální předpovědi ve smyslu minimální chyby **MSE** je pak  $E \hat{y}_t | Y_{t-1}$ , přičemž chyba této předpovědi je

$$(4) \quad e_t = y_t - E \hat{y}_t | Y_{t-1}$$

Má vlastnosti bílého šumu a označuje se jako **inovace [innovation]**. Označení je vcelku logické, protože inovační proces  $\hat{a}_t$  odpovídá nepredikovatelnému pohybu v hodnotách  $\hat{y}_t$ . Jestliže je navíc proces  $\hat{y}_t$  normálně rozdělen, pak podmíněná střední hodnota  $E \hat{y}_t | Y_{t-1}$  má tvar lineární kombinace hodnot  $\hat{y}_{t-1}, y_{t-2}, \dots$  a vztah (4) můžeme přepsat jako

$$(5) \quad e_t = y_t - \pi_1 y_{t-1} - \pi_2 y_{t-2} - \dots,$$

což je právě invertovaný tvar (2) lineárního procesu.

<sup>1</sup> Řekneme, že posloupnost náhodných veličin  $\hat{X}_t$  konverguje k n.v.  $X$  podle středu (je cauchyovská podle středu), jestliže  $\lim_{t \rightarrow \infty} E |X_t - X| = 0$ , resp.  $\lim_{s, t \rightarrow \infty} E |X_t - X_s| = 0$

**Poznámka2** Protože platí  $\varepsilon_t = \pi(B) \cdot y_t = \pi(B) \psi(B) \varepsilon_t$ , musí zřejmě platit

$$(6) \quad \pi(B) \psi(B) = 1$$

$$(6A) \quad \psi_1 - \pi_1 = 0, \quad \psi_2 - \psi_1 \pi_1 - \pi_2 = 0, \quad \psi_3 - \psi_2 \pi_1 - \psi_1 \pi_2 - \pi_3 = 0 \text{ atd.}$$

Tyto vztahy lze použít pro převod parametrů  $\psi_j$  na parametry  $\pi_j$  a naopak. Formálně lze také uplatnit zápis

$$(7) \quad \pi(B) = \psi(B)^{-1}$$

### Proces klouzavých součtů MA [moving average process]<sup>2</sup>

**Proces klouzavých součtů řádu  $q$**  se značí  $MA(q)$  má tvar

$$(11) \quad y_t = \varepsilon_t + \vartheta_1 \varepsilon_{t-1} + \vartheta_2 \varepsilon_{t-2} + \dots + \vartheta_q \varepsilon_{t-q} = \vartheta(B) \cdot \varepsilon_t$$

kde  $\theta_1, \theta_2, \dots, \theta_q$  jsou parametry a  $\vartheta(B) = 1 + \vartheta_1 B + \dots + \vartheta_q B^q$  je tzv. **operátor klouzavých součtů**. Proces  $MA(q)$  tedy zřejmě vzniká useknutím lineárního procesu (1) v bodě, který odpovídá zpoždění  $q$ .

**Proces  $MA(q)$  je vždy stacionární**, má nulovou střední hodnotu a rozptyl velikosti

$$(12) \quad \sigma_y^2 = (1 + \vartheta_1^2 + \vartheta_2^2 + \dots + \vartheta_q^2) \sigma_\varepsilon^2 \text{ a má}$$

**autokorelační funkci**

$$(13) \quad \rho_k = \frac{\theta_k + \vartheta_1 \theta_{k-1} + \dots + \vartheta_{q-k} \theta_q}{1 + \vartheta_1^2 + \vartheta_2^2 + \dots + \vartheta_q^2} \text{ pro } k = 1, 2, \dots, q$$

$$\rho_k = 0 \text{ pro } k > q$$

Autokorelační funkce má tedy bod useknutí  $k_0$  roven řádu modelu  $q$ .

ověření:

$$\rho_1 = \frac{\text{cov}(y_t, y_{t-1})}{\sqrt{\sigma_y^2} \sqrt{\sigma_y^2}} = \frac{\text{cov}(\varepsilon_t + \vartheta_1 \varepsilon_{t-1}, \varepsilon_{t-1} + \vartheta_1 \varepsilon_{t-2})}{\sqrt{\sigma_\varepsilon^2 (1 + \vartheta_1^2)} \sqrt{\sigma_\varepsilon^2 (1 + \vartheta_1^2)}} =$$

$$\frac{\text{cov}(\varepsilon_t \varepsilon_{t-1}) + \vartheta_1 \text{cov}(\varepsilon_t \varepsilon_{t-2}) + \vartheta_1 \text{var}(\varepsilon_{t-1}) + \vartheta_1^2 \text{cov}(\varepsilon_{t-1} \varepsilon_{t-2})}{\sqrt{\sigma_\varepsilon^4 (1 + \vartheta_1^2)^2}} = \frac{\theta_1 \sigma_\varepsilon^2}{\sigma_\varepsilon^2 (1 + \vartheta_1^2)} = \frac{\theta_1}{1 + \vartheta_1^2}$$

**Parciální autokorelační funkce**  $\rho_{kk}$  procesu  $MA(q)$  nemá bod useknutí, ale je omezena lineární kombinací geometricky klesajících posloupností a sinusoid s geometricky klesajícími amplitudami.

Proces  $MA(q)$  je invertibilní, jestliže všechny kořeny  $z_1, z_2, \dots, z_q$  polynomu  $\vartheta(z)$  leží **vně** jednotkového kruhu v komplexní rovině (tj.  $|z_1| > 1, |z_2| > 1, \dots, |z_q| > 1$ ), neboť potom je splněn předpoklad (3).

<sup>2</sup> MA proces nemá žádnou přímou souvislost s dříve popsanou **metodou klouzavých průměrů** užívanou pro eliminaci trendu časové řady.

**Proces  $MA(1)$  - proces klouzavých součtů 1. řádu**

(14)  $y_t = \varepsilon_t + \theta_1 \varepsilon_{t-1}$

má **autokorelační funkci**

$$\rho_k = \frac{\theta_1}{1 + \theta_1^2}, \quad \rho_k = 0 \quad \text{pro } k > 1$$

s bodem useknutí  $k_0 = 1$ .

ověření: vyjdeme z definice (6)

$$\rho_1 = \frac{\gamma_1}{\sigma_y^2} = \frac{\text{cov}(y_t, y_{t-1})}{\sqrt{\text{var } y_t} \sqrt{\text{var } y_{t-1}}} = \frac{\text{cov}(y_t, y_{t-1})}{\sigma_y \cdot \sigma_{y_{t-1}}} \quad \text{a vypočítáme}$$

$$\rho_1 = \frac{\text{cov}(y_t, y_{t-1})}{\sqrt{\sigma_{y_t}^2 \sigma_{y_{t-1}}^2}} = \frac{\text{cov}(\varepsilon_t + \theta_1 \varepsilon_{t-1}, \varepsilon_{t-1} + \theta_1 \varepsilon_{t-2})}{\sqrt{\sigma_{\varepsilon_t}^2 (1 + \theta_1^2) \sigma_{\varepsilon_{t-1}}^2 (1 + \theta_1^2)}} =$$

$$\frac{\text{cov}(\varepsilon_t \varepsilon_{t-1}) + \theta_1 \text{cov}(\varepsilon_t \varepsilon_{t-2}) + \theta_1 \text{var}(\varepsilon_{t-1}) + \theta_1^2 \text{cov}(\varepsilon_{t-1} \varepsilon_{t-2})}{\sqrt{\sigma_{\varepsilon}^4 (1 + \theta_1^2)^2}} = \frac{\theta_1 \sigma_{\varepsilon}^2}{\sigma_{\varepsilon}^2 (1 + \theta_1^2)} = \frac{\theta_1}{1 + \theta_1^2}$$

protože ze čtyř členů v čitateli je jen jeden nenulový a dále platí

$$\text{var } y_t = \text{var } y_{t-1} = \sigma_{\varepsilon_t}^2 + \theta_1^2 \sigma_{\varepsilon_{t-1}}^2 = \sigma_{\varepsilon}^2 (1 + \theta_1^2)$$

(Při odvozování respektujeme pravidlo nekorelovanosti náhodných složek  $\varepsilon_t, \varepsilon_s$  pro  $t \neq s$ .)

$$\rho_k = \frac{\text{cov}(y_t, y_{t-k})}{\sqrt{\sigma_{y_t}^2 \sigma_{y_{t-k}}^2}} = \frac{\text{cov}(\varepsilon_t + \theta_1 \varepsilon_{t-1}, \varepsilon_{t-k} + \theta_1 \varepsilon_{t-k-1})}{\sqrt{\sigma_{\varepsilon_t}^2 (1 + \theta_1^2) \sigma_{\varepsilon_{t-k}}^2 (1 + \theta_1^2)}} =$$

$$\frac{\text{cov}(\varepsilon_t \varepsilon_{t-k}) + \theta_1 \text{cov}(\varepsilon_{t-1} \varepsilon_{t-k}) + \theta_1 \text{cov}(\varepsilon_t \varepsilon_{t-k-1}) + \theta_1^2 \text{cov}(\varepsilon_{t-1} \varepsilon_{t-k-1})}{\sqrt{\sigma_{\varepsilon}^4 (1 + \theta_1^2)^2}} = 0$$

protože při  $k \geq 2$  se ve jmenovateli neobjeví žádné dvě složky  $\varepsilon_s, \varepsilon_t$  se stejným indexem.  $\square$

Jeho **parciální autokorelační funkce**  $\rho_{kk}$  má tvar (bez bodu useknutí):

(15)  $\rho_{kk} = \frac{\theta_1^k (1 - \theta_1^2)}{1 - \theta_1^{2k+1}}$  pro  $k = 1, 2, 3, \dots$

Takže je v případě **invertibility** procesu opravdu neomezená geometricky klesající posloupnost

(16)  $|\rho_{kk}| = \frac{\theta_1}{1 + \theta_1^2}$

**Podmínka invertibility** zde má totiž velmi jednoduchý tvar  $|\theta_1| < 1$ . Protože

$\rho_1 = \frac{\theta_1}{1 + \theta_1^2}$ , musí pro invertibilní  $MA(1)$  proces být  $|\rho_1| = \left| \frac{\theta_1}{1 + \theta_1^2} \right| < 0,5$ . Tato

nerovnost platí dokonce pro všechna  $|\theta_1| \neq 1$ .

**Proces  $MA(2)$  - proces klouzavých součtů 2. řádu**

(17)  $y_t = \varepsilon_t + \theta_1 \varepsilon_{t-1} + \theta_2 \varepsilon_{t-2}$

má **autokorelační funkci**

(18) 
$$\rho_k = \frac{\theta_1 + \theta_2 \theta_1}{1 + \theta_1^2 + \theta_2^2} \text{ pro } k=1$$

$$= \frac{\theta_2}{1 + \theta_1^2 + \theta_2^2} \text{ pro } k=2$$

$$= 0 \text{ pro } k > 2$$

s bodem useknutí  $k_0 = 2$ .

ověření:

$$\rho_1 = \frac{\text{cov}(y_t, y_{t-1})}{\sqrt{\sigma_{y_t}^2 \sigma_{y_{t-1}}^2}} = \frac{\text{cov}(\varepsilon_t + \theta_1 \varepsilon_{t-1} + \theta_2 \varepsilon_{t-2}, \varepsilon_{t-1} + \theta_1 \varepsilon_{t-2} + \theta_2 \varepsilon_{t-3})}{\sqrt{\sigma_{\varepsilon}^2 (1 + \theta_1^2 + \theta_2^2) \sigma_{\varepsilon}^2 (1 + \theta_1^2 + \theta_2^2)}} =$$

$$\frac{\theta_1 \text{cov}(\varepsilon_{t-1}, \varepsilon_{t-1}) + \theta_2 \theta_1 \text{cov}(\varepsilon_{t-2}, \varepsilon_{t-2})}{\sqrt{\sigma_{\varepsilon}^4 (1 + \theta_1^2 + \theta_2^2)^2}} = \frac{\theta_1 \sigma_{\varepsilon}^2 + \theta_2 \theta_1 \sigma_{\varepsilon}^2}{\sigma_{\varepsilon}^2 (1 + \theta_1^2 + \theta_2^2)} = \frac{\theta_1 + \theta_2 \theta_1}{1 + \theta_1^2 + \theta_2^2}$$

$$\rho_2 = \frac{\text{cov}(y_t, y_{t-2})}{\sqrt{\sigma_{y_t}^2 \sigma_{y_{t-2}}^2}} = \frac{\text{cov}(\varepsilon_t + \theta_1 \varepsilon_{t-1} + \theta_2 \varepsilon_{t-2}, \varepsilon_{t-2} + \theta_1 \varepsilon_{t-3} + \theta_2 \varepsilon_{t-4})}{\sqrt{\sigma_{\varepsilon}^2 (1 + \theta_1^2 + \theta_2^2) \sigma_{\varepsilon}^2 (1 + \theta_1^2 + \theta_2^2)}} =$$

$$\frac{\theta_2 \text{cov}(\varepsilon_{t-2}, \varepsilon_{t-2})}{\sqrt{\sigma_{\varepsilon}^4 (1 + \theta_1^2 + \theta_2^2)^2}} = \frac{\theta_2 \sigma_{\varepsilon}^2}{\sigma_{\varepsilon}^2 (1 + \theta_1^2 + \theta_2^2)} = \frac{\theta_2}{1 + \theta_1^2 + \theta_2^2}$$

$$\rho_k = \frac{\text{cov}(y_t, y_{t-k})}{\sqrt{\sigma_{y_t}^2 \sigma_{y_{t-k}}^2}} = \frac{\text{cov}(\varepsilon_t + \theta_1 \varepsilon_{t-1} + \theta_2 \varepsilon_{t-2}, \varepsilon_{t-k} + \theta_1 \varepsilon_{t-k-1} + \theta_2 \varepsilon_{t-k-2})}{\sqrt{\sigma_{\varepsilon}^2 (1 + \theta_1^2 + \theta_2^2) \sigma_{\varepsilon}^2 (1 + \theta_1^2 + \theta_2^2)}} =$$

$$\frac{0}{\sqrt{\sigma_{\varepsilon}^4 (1 + \theta_1^2 + \theta_2^2)^2}} = 0$$

protože při  $k \geq 3$  se ve jmenovateli neobjeví žádné dvě složky  $\varepsilon_s, \varepsilon_t$  se stejným indexem.

Při odvozování respektujeme pravidlo nekorelovanosti náhodných složek  $\varepsilon_t, \varepsilon_s$  pro  $t \neq s$ . □

**Podmínka invertibility (2) má pro proces  $MA(2)$  tvar**

(19)  $|\theta_1 + \theta_2| < 1, |\theta_2 - \theta_1| < 1, -1 < \theta_2 < 1,$

takže **oblast invertibility procesu  $MA(2)$  v rovině s vodorovnou osou pro hodnoty  $\theta_1$  a se svislou osou pro hodnoty  $\theta_2$  vyplní vnitřek trojúhelníka s vrcholy  $(-1, 1), (1, 1)$  a  $(0, -1)$ .**

## Autoregresní proces AR [autoregressive process]

Autoregresní proces řádu  $p$  se značí  $AR(p)$  má tvar

$$(21) \quad y_t = \phi_1 y_{t-1} + \phi_2 y_{t-2} + \dots + \phi_p y_{t-p} + \varepsilon_t = \phi(B) \cdot y_t + \varepsilon_t \text{ neboli}$$

$$(21A) \quad y_t - \phi_1 y_{t-1} - \phi_2 y_{t-2} - \dots - \phi_p y_{t-p} = \phi(B) \cdot y_t = \varepsilon_t, \text{ kde}$$

$\phi_1, \phi_2, \dots, \phi_p$  jsou parametry a  $\phi(B) = 1 - \phi_1 B + \phi_2 B^2 - \dots - \phi_p B^p$  je tzv. **autoregresní operátor**.

Proces  $AR(p)$  zřejmě vzniká useknutím lineárního procesu v bodě, který odpovídá velikosti zpoždění  $p$ .

Proces  $AR(p)$  je stacionární, jestliže všechny kořeny  $z_1, z_2, \dots, z_p$  polynomu  $\phi(z)$

leží vně jednotkového kruhu v komplexní rovině (tj. pro všechna  $|z_1|, |z_2|, \dots, |z_p| > 1$ ),

protože pak je splněn předpoklad (3). Proces má v tom případě nulovou střední hodnotu a jeho **rozptyl je roven**

$$(22) \quad \sigma_y^2 = \frac{\sigma_\varepsilon^2}{1 - \phi_1 \rho_1 - \phi_2 \rho_2 - \dots - \phi_p \rho_p}.$$

ověření: Definiční vyjádření procesu (21) vynásobíme  $y_t$ , a uplatníme střední hodnotu:

$$y_t \cdot y_t = \phi_1 y_t \cdot y_{t-1} + \phi_2 y_t \cdot y_{t-2} + \dots + \phi_p y_t \cdot y_{t-p} + y_t \cdot \varepsilon_t$$

$$(23) \quad E y_t \cdot y_t = \phi_1 E y_t \cdot y_{t-1} + \phi_2 E y_t \cdot y_{t-2} + \dots + \phi_p E y_t \cdot y_{t-p} + E y_t \cdot \varepsilon_t.$$

Vztah (23) podělíme rozptylem veličiny  $y_t$ . Dostaneme:

$$\frac{E y_t^2}{\sigma_y^2} = \phi_1 \frac{E y_t \cdot y_{t-1}}{\sigma_y^2} + \phi_2 \frac{E y_t \cdot y_{t-2}}{\sigma_y^2} + \dots + \phi_p \frac{E y_t \cdot y_{t-p}}{\sigma_y^2} + \frac{E y_t \cdot \varepsilon_t}{\sigma_y^2}.$$

Zřejmě máme  $E y_t^2 = \sigma_y^2$  a  $\frac{E y_t \cdot y_{t-k}}{\sigma_y^2} = \rho_k$ , takže dostaneme

$$1 = \phi_1 \rho_1 + \phi_2 \rho_2 + \dots + \phi_p \rho_p + \frac{\sigma_\varepsilon^2}{\sigma_y^2}, \text{ resp. } 1 - \phi_1 \rho_1 - \phi_2 \rho_2 - \dots - \phi_p \rho_p = \frac{\sigma_\varepsilon^2}{\sigma_y^2}, \text{ a po}$$

vynásobení obou stran strany rozptylem  $y_t$

$$\sigma_y^2 \cdot (1 - \phi_1 \rho_1 - \phi_2 \rho_2 - \dots - \phi_p \rho_p) = \sigma_\varepsilon^2, \text{ z čehož plyne (22).} \quad \square.$$

a jeho **autokorelační funkce** splňuje diferenční rovnici

$$(24) \quad \rho_k = \phi_1 \rho_{k-1} + \phi_2 \rho_{k-2} + \dots + \phi_p \rho_{k-p} \text{ pro } k > 0.$$

**Poznámka** Pro odvození (24) stačí vynásobit všechny členy rovnosti (21) výrazem  $y_{t-k} / \sigma_y^2$  a přejít ke středním hodnotám, přičemž vzhledem k možnosti vyjádření stacionárního  $AR(p)$  procesu jako lineárního procesu (1), je  $E y_{t-k} \cdot \varepsilon_t = 0$  pro  $k > 0$ :

$$(21) \quad \frac{y_t y_{t-1}}{\sigma_y^2} = \frac{\phi_1 y_{t-1} y_{t-1} + \phi_2 y_{t-2} y_{t-1} + \dots + \phi_p y_{t-p} y_{t-1} + \varepsilon_t y_{t-1}}{\sigma_y^2} \text{ a dále}$$

$$\frac{E\{y_t y_{t-1}\}}{\sigma_y^2} = \frac{\phi_1 E\{y_{t-1} y_{t-1}\} + \phi_2 E\{y_{t-2} y_{t-1}\} + \dots + \phi_p E\{y_{t-p} y_{t-1}\} + E\{\varepsilon_t y_{t-1}\}}{\sigma_y^2}, \text{ takže}$$

$$\rho_k = \frac{E\{y_t y_{t-k}\}}{\sigma_y^2} = \phi_1 \frac{E\{y_{t-1} y_{t-1}\}}{\sigma_y^2} + \phi_2 \frac{E\{y_{t-2} y_{t-1}\}}{\sigma_y^2} + \dots + \phi_p \frac{E\{y_{t-p} y_{t-1}\}}{\sigma_y^2} + \frac{E\{\varepsilon_t y_{t-k}\}}{\sigma_y^2}$$

Neboli  $\rho_k = \phi_1 \rho_{k-1} + \phi_2 \rho_{k-2} + \dots + \phi_p \rho_{k-p} + 0$  □.

Z teorie diferenčních rovnic přitom plyne, že její řešení (24) lze vyjádřit ve tvaru

$$(25) \quad \rho_k = \alpha_1 z_1^{-k} + \alpha_2 z_2^{-k} + \dots + \alpha_p z_p^{-k} \text{ pro } k \geq 0, \text{ kde}$$

$z_1, z_2, \dots, z_p$  jsou navzájem různé kořeny polynomu  $\phi(z)$  s vlastnostmi

$|z_1|, |z_2|, \dots, |z_p| > 1$  a  $\alpha_1, \alpha_2, \dots, \alpha_p$  jsou pevné koeficienty:

a) Pokud jsou kořeny  $z_i, z_j$  komplexně sdružené, pak mohou být nahrazeny jediným členem tvaru  $\alpha \cdot d^k \cdot \sin(\lambda k + \theta)$  s  $0 < d < 1$ .

b) Pokud kořeny  $z_i, z_j$  nejsou navzájem různé, tzn. některý z nich je násobný, pak se pro kořen  $z_i$  s násobností  $r$  ve vyjádření objeví složitější člen typu  $(\beta_0 + \beta_1 k + \beta_2 k^2 + \dots + \beta_r k^{r-1}) z_i^{-k}$ , který je však výrazně překrýván průběhem členu  $z_i^{-k}$ . Tak či onak, je **autokorelační funkce procesu**  $AR(p)$  v podstatě lineární kombinací **klesajících geometrických posloupností** a **sinusoid různých frekvencí s geometricky klesajícími amplitudami**.

### soustava Yule-Walkerových rovnic

Jestliže zapíšeme výraz (23) jen pro  $k = 1, 2, \dots, p$ , pak dostaneme tzv. **soustavu Yuleových-Walkerových rovnic** pro vyjádření parametrů  $\phi_1, \phi_2, \dots, \phi_p$  pomocí autokorelací  $\rho_1, \rho_2, \dots, \rho_p$  (a naopak).

$$(26) \quad \begin{aligned} \rho_1 &= \phi_1 + \phi_2 \rho_1 + \dots + \phi_p \rho_{p-1} \\ \rho_2 &= \phi_1 \rho_1 + \phi_2 + \dots + \phi_p \rho_{p-2} \\ &\dots \\ \rho_p &= \phi_1 \rho_{p-1} + \phi_2 \rho_{p-2} + \dots + \phi_p \end{aligned}$$

**Parciální autokorelační funkce**  $\rho_{kk}$  procesu  $AR(p)$  má bod useknutí  $k_0$  rovný řádu modelu  $p$ . To plyne přímo z definice parciální autokorelační funkce, což činí z této funkce důležitý nástroj pro identifikaci autoregresních procesů.

**Proces**  $AR(p)$  je vždy invertibilní. Je to zřejmé, neboť (23) je již zápis tohoto modelu v invertovaném tvaru.

### Proces $AR(1)$ - autoregresní proces 1. řádu

(27)  $y_t = \phi_1 y_{t-1} + \varepsilon_t$  je stacionární pro  $|\phi_1| < 1$

V tomto případě má nulovou střední hodnotu a rozptyl procesu  $AR(1)$  je roven

(28) 
$$\sigma_y^2 = \frac{\sigma^2}{1 - \phi_1^2}$$

Jeho autokorelační funkce má tvar

(29) 
$$\rho_k = \phi_1^k \text{ pro } k = 0, 1, 2, 3, \dots$$

ve tvaru geometricky klesající posloupnosti (oscilující pro záporné  $\phi_1$  a bez bodu useknutí). Speciálně je pro  $k = 1$

(30)  $\rho_1 = \phi_1$ , což znamená, že

$\rho_1 = \phi_1$  první autokorelace procesu  $AR(1)$  se rovná právě jeho autoregresnímu parametru. Proto důležitou roli v modelu hraje znaménko parametru  $\phi_1$ .

a) Pokud platí  $\phi_1 > 0$  (pozitivní autokorelovanost), pak je patrná setrvačnost ve znaménkách sousedních hodnot (s relativně malým překřížením časové osy)

b) Pokud platí  $\phi_1 < 0$  (negativní autokorelovanost), pak to signalizuje relativně velmi časté přechody hodnot přes časovou osu, a velmi časté změny ve znaménkách sousedních hodnot časové řady.

Parciální autokorelační funkce procesu  $AR(1)$  má tvar

(31)  $\rho_{11} = \phi_1$ ,  $\rho_{kk} = 0$  pro  $k > 1$

s bodem useknutí  $k_0 = 1$ .

### Proces $AR(2)$ - autoregresní proces 2. řádu

(32)  $y_t = \phi_1 y_{t-1} + \phi_2 y_{t-2} + \varepsilon_t$  je stacionární pro

(32A)  $\phi_1 + \phi_2 < 1$ ,  $\phi_2 - \phi_1 < 1$   $-1 < \phi_2 < 1$ ,

takže příslušná oblast stacionarity  $AR(2)$  v rovině s vodorovnou osou pro hodnoty  $\phi_1$  a svislou osou pro hodnoty  $\phi_2$  vyplní vnitřek trojúhelníka v vrcholy

s vodorovnou osou pro hodnoty  $\theta_1$  a se svislou osou pro hodnoty  $\theta_2$  vyplní vnitřek trojúhelníka s vrcholy  $(-2, -1)$ ,  $(0, 1)$  a  $(0, -1)$ . V tom případě má proces  $AR(2)$  nulovou střední hodnotu a rozptyl roven

(33) 
$$\sigma_y^2 = \frac{\sigma^2}{1 - \phi_1 \rho_1 - \phi_2 \rho_2}$$

a jeho autokorelační funkce má tvar

$$\rho_k = \frac{z_1^{-k} - z_2^{-k}}{z_1 - z_2} \text{ pro } k \geq 0, \text{ kde}$$

$z_1, z_2$  jsou navzájem různé kořeny polynomu  $\phi(z)$  ( $|z_1|, |z_2| > 1$ ; pro dvojnásobný kořen je tvar funkce analogický),  $\rho_k$  nemá bod useknutí a má tvar lineární kombinace dvou geometricky klesajících posloupností nebo tvar sinusoidy s geometricky klesající amplitudou.

**Parciální autokorelační funkce procesu  $AR(2)$  má bod useknutí roven  $k_0 = 2$ .**

### Smíšený proces ARMA [autoregressive and moving averages process]

Smíšený proces řádu  $p$  a  $q$  značený jako  $ARMA(p, q)$  má tvar:

$$(41) \quad y_t = \phi_1 y_{t-1} + \phi_2 y_{t-2} + \dots + \phi_p y_{t-p} + \varepsilon_t + \theta_1 \varepsilon_{t-1} + \dots + \theta_q \varepsilon_{t-q} \quad \text{neboli}$$

$$(41A) \quad \phi(B)y_t = \vartheta \varepsilon_t,$$

kde operátory  $\phi(B)$  a  $\vartheta(B)$  byly zavedeny v procesech  $AR(p)$  a  $MA(q)$ . Podmínka stacionarity (resp. invertibility) smíšeného procesu  $ARMA(p, q)$  je shodná s podmínkou procesu  $AR(p)$  (resp. invertibility procesu  $MA(q)$ ).

**Stacionární proces  $ARMA(p, q)$  má nulovou střední hodnotu a jeho autokorelační funkce splňuje diferenční rovnici**

$$(42) \quad \rho_k = \phi_1 \rho_{k-1} + \phi_2 \rho_{k-2} + \dots + \phi_p \rho_{k-p} \quad \text{pro } k \geq q + 1$$

s řešením

$$(43) \quad \rho_k = \alpha_1 z_1^{-k} + \alpha_2 z_2^{-k} + \dots + \alpha_p z_p^{-k} \quad \text{pro } k \geq \max\{q, q - p + 1\},$$

kde  $z_1, z_2, \dots, z_p$  jsou navzájem různé kořeny polynomu  $\phi(z)$ ,  $|z_1|, |z_2|, \dots, |z_p| > 1$ .

**Autokorelační funkce procesu  $ARMA(p, q)$  nemá bod useknutí a je v podstatě lineární kombinací klesajících geometrických posloupností a sinusoid různých frekvencí s geometricky klesajícími amplitudami, ale s výjimkou počátečních hodnot  $\rho_0, \rho_1, \rho_2, \dots, \rho_{q-p}$  (tato výjimka se uplatní jen v případě  $q \geq p$ ).**

**Parciální autokorelační funkce procesu  $ARMA(p, q)$  nemá bod useknutí a je omezena lineární kombinací klesajících geometrických posloupností a sinusoid různých frekvencí s geometricky klesajícími amplitudami, ale s výjimkou počátečních hodnot  $\rho_{0,0}, \rho_{1,1}, \rho_{2,2}, \dots, \rho_{p-1,p-1}$  (výjimka se uplatní, jen když  $p \geq 1$ ).**

Proces  $ARMA(1,1)$  je představován zápisem

$$(44) \quad y_t = \phi_1 y_{t-1} + \varepsilon_t + \theta_1 \varepsilon_{t-1}$$

a je stacionární pro  $|\phi_1| < 1$ . V tom případě má nulovou střední hodnotu a rozptyl roven

$$(45) \quad \sigma_y^2 = \frac{1 + \vartheta^2 + 2\phi_1\theta_1}{1 - \phi_1^2} \sigma_\varepsilon^2.$$



**ověření:** Z definice procesu  $ARMA(1,1)$  ve (44) víme, že platí

$$y_t \cdot y_t = (\phi_1 y_{t-1} + \varepsilon_t + \theta_1 \varepsilon_{t-1}) (\phi_1 y_{t-1} + \varepsilon_t + \theta_1 \varepsilon_{t-1}), \text{ takže}$$

$$E y_t \cdot y_t = E (\phi_1 y_{t-1} + \varepsilon_t + \theta_1 \varepsilon_{t-1})^2, \text{ po roznásobení pak}$$

$$\begin{aligned} E y_t^2 &= \phi_1^2 E y_{t-1}^2 + E \varepsilon_t^2 + \theta_1^2 E \varepsilon_{t-1}^2 + 2\phi_1 E y_{t-1} \varepsilon_t + 2\theta_1 E \varepsilon_{t-1} \varepsilon_t + 2\phi_1 \theta_1 E y_{t-1} \varepsilon_{t-1} \\ E y_t^2 &= \phi_1^2 E y_{t-1}^2 + E \varepsilon_t^2 + \theta_1^2 E \varepsilon_{t-1}^2 + 2\phi_1 E y_{t-1} \varepsilon_t + 2\theta_1 \phi_1 E y_{t-1} \varepsilon_{t-1} \\ E y_t^2 &= \phi_1^2 E y_{t-1}^2 + \sigma_\varepsilon^2 + \theta_1^2 \sigma_\varepsilon^2 + 2\phi_1 E y_{t-1} \varepsilon_t + 2\theta_1 \phi_1 E y_{t-1} \varepsilon_{t-1} \end{aligned}$$

**Vztah** podělíme rozptylem veličiny  $y_t$ . Dostaneme (protože  $2\phi_1 E y_{t-1} \varepsilon_t = 0$ ):

$$\frac{E y_t^2}{\sigma_y^2} = \frac{\phi_1^2 E y_{t-1}^2}{\sigma_y^2} + \frac{\sigma_\varepsilon^2}{\sigma_y^2} + \frac{\theta_1^2 \sigma_\varepsilon^2}{\sigma_y^2} + \frac{2\theta_1 \phi_1 E y_{t-1} \varepsilon_{t-1}}{\sigma_y^2}$$

$$1 = \phi_1^2 + \frac{\sigma_\varepsilon^2}{\sigma_y^2} + \frac{\theta_1^2 \sigma_\varepsilon^2}{\sigma_y^2} + \frac{2\theta_1 \phi_1 \sigma_\varepsilon^2}{\sigma_y^2}$$

$$(1 - \phi_1^2) \sigma_y^2 = \sigma_\varepsilon^2 + \theta_1^2 \sigma_\varepsilon^2 + 2\theta_1 \phi_1 \sigma_\varepsilon^2$$

a následně obdržíme shodu s (45)

$$\sigma_y^2 = \frac{\sigma_\varepsilon^2 + \theta_1^2 \sigma_\varepsilon^2 + 2\theta_1 \phi_1 \sigma_\varepsilon^2}{(1 - \phi_1^2)} = \frac{(1 + \theta_1^2 + 2\theta_1 \phi_1) \sigma_\varepsilon^2}{(1 - \phi_1^2)} \quad \square.$$

a má **autokorelační funkci**

(46)

$$\rho_1 = \frac{(1 + \phi_1 \theta_1) (\phi_1 + \theta_1)}{1 + \theta_1^2 + 2\phi_1 \theta_1} \sigma_\varepsilon^2$$

**ověření:**

podle (6) a (44) máme

$$\rho_1 = \frac{\text{cov}(y_t, y_{t-1})}{\sigma_y \sigma_{y-1}} = \frac{E y_t y_{t-1}}{\sigma_y^2} = \frac{E (\phi_1 y_{t-1} + \varepsilon_t + \theta_1 \varepsilon_{t-1}) (\phi_1 y_{t-2} + \varepsilon_{t-1} + \theta_1 \varepsilon_{t-2})}{\sigma_y^2}$$

**Výraz** ve čitateli předchozího zlomku lze rozepsat následovně:

$$\begin{aligned} E (\phi_1 y_{t-1} + \varepsilon_t + \theta_1 \varepsilon_{t-1}) (\phi_1 y_{t-2} + \varepsilon_{t-1} + \theta_1 \varepsilon_{t-2}) &= \\ E \phi_1^2 y_{t-1} y_{t-2} + E \phi_1 y_{t-1} \varepsilon_{t-1} + E \phi_1 y_{t-1} \theta_1 \varepsilon_{t-2} &+ \\ + E \varepsilon_t \phi_1 y_{t-2} + E \varepsilon_t \varepsilon_{t-1} + E \varepsilon_t \theta_1 \varepsilon_{t-2} + & \\ + E \theta_1 \varepsilon_{t-1} \phi_1 y_{t-2} + E \theta_1 \varepsilon_{t-1}^2 + E \theta_1^2 \varepsilon_{t-1} \varepsilon_{t-2} & \end{aligned}$$

**Vyjádříme-li** jednotlivé členy předchozího devítičlenu, dostaneme:

$$E \phi_1^2 y_{t-1} y_{t-2} = \phi_1^2 E y_{t-1} y_{t-2} =$$

$$E \phi_1 y_{t-1} \varepsilon_{t-1} = \phi_1 E y_{t-1} \varepsilon_{t-1} = \phi_1 \sigma_\varepsilon^2$$

$$E \phi_1 y_{t-1} \theta_1 \varepsilon_{t-2} = \phi_1 \theta_1 E y_{t-1} \varepsilon_{t-2} = \phi_1 \theta_1^2 \sigma_\varepsilon^2$$

$$E \varepsilon_t \phi_1 y_{t-2} = \phi_1 E \varepsilon_t y_{t-2} = 0$$

$$E\{\varepsilon_t | \varepsilon_{t-1}\} = 0$$

$$E\{\varepsilon_t \theta | \varepsilon_{t-1}\} = \theta \cdot E\{\varepsilon_t | \varepsilon_{t-1}\} = 0$$

$$E\{\theta \varepsilon_t \phi | y_{t-1}\} = \theta \phi \cdot E\{\varepsilon_t | y_{t-1}\} = 0$$

$$E\{\theta^2 \varepsilon_t^2\} = \theta^2 E\{\varepsilon_t^2\} = \theta^2 \sigma_\varepsilon^2$$

$$E\{\theta^2 \varepsilon_t \varepsilon_{t-1}\} = \theta^2 E\{\varepsilon_t \varepsilon_{t-1}\} = 0$$

$$\rho_1 = \frac{xx + b_1 \sigma_\varepsilon^2 + b_1 \theta^2 \sigma_\varepsilon^2 + \vartheta_1 \sigma_\varepsilon^2}{\sigma_y^2} = \frac{\sigma_\varepsilon^2 (xx + b_1 + b_1 \theta^2 + \vartheta_1)}{\sigma_y^2}$$

$$\rho_1 = \frac{xx + b_1 \sigma_\varepsilon^2 + b_1 \theta^2 \sigma_\varepsilon^2 + \vartheta_1 \sigma_\varepsilon^2}{\sigma_y^2} = \frac{\sigma_\varepsilon^2 (xx + b_1 + b_1 \theta^2 + \vartheta_1)}{\frac{1 + \vartheta_1^2 + 2\phi_1 \theta_1}{1 - b_1^2} \cdot \sigma_\varepsilon^2}$$

$$(47) \quad \rho_k = \phi_1 \rho_{k-1} \quad \text{pro } k \geq 2$$

bez bodu useknutí ve tvaru klesající geometrické posloupnosti s výjimkou  $\rho_0$

**Podmínkou invertibility procesu**  $ARMA(1,1)$  je  $|\phi_1| < 1$ .

Parciální  $\rho_{kk}$  autokorelační funkce procesu  $ARMA(1,1)$  je omezena klesající geometrickou posloupností počínaje od  $\rho_{11}$ .

### Zobecnění stacionární proces s úroňovou konstantou

Dosud uvedené stacionární procesy se vyznačovaly nulovou střední hodnotou. Jejich zobecnění pro situace, kdy je střední hodnota nenulová (ale zůstává v čase neměnná) není však nijak obtížné:

Vezmeme-li

**Proces klouzavých součtů řádu**  $MA(q)$  se střední hodnotou  $\mu$  má tvar

$$(51) \quad y_t = \mu + \varepsilon_t + \vartheta_1 \varepsilon_{t-1} + \vartheta_2 \varepsilon_{t-2} + \dots + \vartheta_q \varepsilon_{t-q} = \mu + \vartheta(B) \cdot \varepsilon_t$$

**Smišený proces**  $ARMA(p,q)$  se střední hodnotou  $\mu$  má tvar

$$(52) \quad y_t - \mu = \phi_1 (y_{t-1} - \mu) + \phi_2 (y_{t-2} - \mu) + \dots + \phi_p (y_{t-p} - \mu) + \varepsilon_t + \theta_1 \varepsilon_{t-1} + \dots + \theta_q \varepsilon_{t-q}$$

neboli

$$(52A) \quad y_t = \alpha + \phi_1 y_{t-1} + \phi_2 y_{t-2} + \dots + \phi_p y_{t-p} + \varepsilon_t + \theta_1 \varepsilon_{t-1} + \dots + \theta_q \varepsilon_{t-q}, \text{ kde}$$

$$\alpha = (1 - \phi_1 - \phi_2 - \dots - \phi_p) \mu$$

## Konstrukce modelů v Boxově-Jenkinsově metodologii

Podobně jako v ekonometrii, sestává úplná tvorba modelu v **Boxově-Jenkinsově metodologii** z následujících třech kroků:

**(A) identifikace modelu** Znamená to např. že pro analyzovanou časovou řadu  $y_1, y_2, \dots, y_n$  identifikujeme jí adekvátní model  $AR(1)$

**(B) odhad parametrů (kvantifikace) modelu.** V rámci modelu  $AR(1)$  se (dejme tomu) jedná o model tvaru  $y_t = 0,72 y_{t-1} + \varepsilon_t$  při  $\sigma_\varepsilon^2 = 8,92$

**(C) diagnostika modelu.** V rámci odhadnutého modelu v (b) je tento model verifikován na hladině významnosti  $\alpha = 0,05$  a prověří se jeho verifikační schopnosti.

Pokud diagnostické výsledky z kroku (C) nejsou dostatečně přesvědčivé, je potřebné všechny tři kroky zopakovat pro alternativní model (často se ale jedná jen o korekci zamítnutého modelu, ke které nám provedená diagnostika poskytla dílčí návod).

## (A) - Identifikace modelu

Příspěvek **autokorelační a parciální autokorelační funkce** k identifikaci modelu:

Obecnější poznatky o tvaru autokorelační a parciální autokorelační funkce stacionárních a invertibilních procesů  $AR(p)$ ,  $MA(q)$ ,  $ARMA(p,q)$  přináší tabulka:

	$AR(p)$	$MA(q)$	$ARMA(p,q)$
$\rho_{kk}$	neexistuje $k_0$	$k_0 = q$	neexistuje $k_0$
$\rho_{kk}$	ve tvaru U-křivky		ve tvaru U-křivky po prvních $q-p$ hodnotách
$\rho_{kk}$	$k_0 = p$	neexistuje $k_0$	$\rho_{kk}$ omezená U-křivkou po prvních $p-q$ hodnotách

Odpovídající identifikační postup pak spočívá v prohlídce grafického záznamu odhadnutého **korelogramu** a **parciálního korelogramu** modelované časové řady, kdy se snažíme řadě přiřadit nejvhodnější typ modelu právě pomocí charakteristik z tabulky. V případě pochybností testujeme potenciální bod useknutí  $k_0$  pomocí **Bartlettovy aproximace** s přibližným (asymptotickým) kritickým oborem (nejčastěji na hladině  $\alpha = 0,05$ ) pro autokorelační funkci

$$(53) \quad |r_k| \geq 2 \cdot \sqrt{\frac{1}{n} \left( 1 + 2 \cdot \sum_{j=1}^{k_0} r_j^2 \right)} \quad \text{pro některé } k > k_0$$

Druhou možností je aplikovat **Quenouilleovu aproximaci** s kritickým oborem (na hladině  $\alpha = 0,05$ ) pro parciální autokorelační funkci

$$(54) \quad |r_{kk}| \geq 2 \cdot \sqrt{\frac{1}{n}} \quad \text{pro některé } k > k_0$$

## Identifikace pomocí informačních kritérií

Jde o modernější přístup k identifikaci, který snižuje míru subjektivity posuzování analytika a v jistém smyslu identifikaci automatizuje. K problému identifikace obecného modelu  $ARMA(p, q)$  pro danou časovou řadu se zde přistupuje jako k problému odhadu parametrů  $p, q$  na základě optimalizačního kritéria

$$(60) \quad \hat{p}, \hat{q} = \arg \min_{(k, l)} A(k, l), \text{ kde}$$

$A(k, l)$  je vhodné kritérium, k jehož konstrukci musíme pro danou řadu odhadnout model  $ARMA(k, l)$ , přičemž minimalizaci provádíme pro předem zvolenou síť hodnot  $k = 1, 2, \dots, K \quad l = 1, 2, \dots, L$ .

Adekvátnější než předchozí postup (60) je však uplatnit některé z **kritérií teorie informace**, kdy se penalizují zbytečně vysoké řády  $l$  a  $k$  a často tak docílit u odhadů jejich konzistence. Nejběžnější kritéria založená na tomto principu jsou

**(A) AKAIKEho informační kritérium [Akaike information criterion]**

$$(61) \quad AIC(k, l) = n \sigma_{k, l}^2 + 2 \cdot \frac{k + l + 1}{n}$$

**(B) SCHWARTZovo informační kritérium [Schwartz (Bayesian) information criterion]**

$$(62) \quad SIC(k, l) = n \sigma_{k, l}^2 + n \ln(n) \cdot \frac{k + l + 1}{n}, \text{ kde}$$

$\sigma_{k, l}^2$  je odhadnutý rozptyl bílého šumu procesu  $ARMA(p, q)$  a v čitateli druhého členu je počet odhadovaných parametrů (se započtením eventuálně nenulové úrovně konstanty  $\mu$ , přičemž  $n$  je délka dané řady). Korektně by ale místo prvních členů v (61), resp. (62) měla být použita minimální hodnota logaritmované věrohodnostní funkce daného modelu vynásobená koeficientem  $(-2/n)$ .

**Kritérium BIC** sice poskytuje silně **konzistentní odhad** řádu modelu (který konverguje skoro jistě, tj. s pravděpodobností 1), ale s velkým rozptylem (tj. odhad ale postrádá **vydatnost**).

**U kritéria AIC** je tomu přesně naopak: příslušný **odhad řádu modelu** je zde bohužel **nekonzistentní, ale je vydatný**.

## Odhad parametrů ARMA modelu

V počáteční fázi kvantifikace modelu se postupuje tak, že se využijí existující vztahy mezi parametry daného modelu a jeho autokorelacemi, kdy např. v modelu  $AR(1)$  platí, že  $\phi_1 = \rho_1$ . Takovéto odhady odvozené z momentů se však zpravidla považují jen za předběžné a slouží tedy jako počáteční odhady pro vlastní odhadové procedury, prováděné většinou iteračně vhodnou numerickou metodou.

**model**                      **momentové odhady**                      **kontrolní nerovnosti pro  $r_k$**

$AR(1)$	$\phi_1 = r_1, \sigma^2 = \sigma_y^2 (1 - \phi_1^2)$	$ r_1  < 1$
$AR(2)$	$\phi_1 = \frac{r_1 - r_2}{1 - r_1^2}, \phi_2 = \frac{r_2 - r_1^2}{1 - r_1^2}, \sigma^2 = \sigma_y^2 (1 - \phi_1^2 - \phi_2^2)$	$ r_2  < 1, r_1^2 < \frac{1 + r_2}{2}$
$MA(1)$	$\theta_1 = \frac{1 - \sqrt{1 - 4r_1^2}}{2r_1}, \sigma^2 = \frac{\sigma_y^2}{1 + \theta_1^2}$	$ r_1  < 1/2$
$MA(2)$	$\theta_1 = \theta_2 = \theta, \sigma^2 = \frac{\sigma_y^2}{1 + \theta_1^2 + \theta_2^2}$	$r_1 + r_2 > -1/2, r_2 - r_1 > -1/2$
$ARMA(1,1)$	$\phi_1 = \frac{r_2}{r_1}, \theta_1 = \frac{\hat{b} \pm \sqrt{\hat{b}^2 - 4}}{2}$	$r_1^2 < 4r_2 < -2r_2, 2r_1^2 -  r_1  < r_2 <  r_1 $
$\hat{b} = \frac{1 - 2r_2 + \phi_1^2}{r_1 - \phi_1}, \sigma^2 = \frac{\sigma_y^2}{1 + \theta_1^2}, \text{ kde } \sigma_y^2 = \frac{\sum_{t=1}^n (y_t^* - \bar{y}^*)^2}{n}, \text{ kde } y_t^* = y_t - \phi_1 y_{t-1}$		

Odhadové procedury pro konstrukci finálních odhadů v uvažovaných modelech jsou vysloveně závislé na metodách nasazených v příslušném software. Např. v  $AR(p)$  modelu zapsanému ve tvaru

$$(21) \quad y_t = \alpha + \phi_1 y_{t-1} + \phi_2 y_{t-2} + \dots + \phi_p y_{t-p} + \varepsilon_t$$

lze použít klasický OLS-odhad spolu s klasickým OLS-odhadem jeho kovarianční matice, který je za předpokladu stacionarity procesu konzistentní. Lze totiž ukázat, že regresory v (21) splňují podmínku  $T \rightarrow \infty, p \lim \left( \frac{1}{T} X'X \right) = V$ , kde  $V$  je regulární

matice a stejně tak i podmínku ortogonality  $T \rightarrow \infty, p \lim \left( \frac{1}{T} X'\varepsilon \right) = 0$ . Z vyjádření stacionárního procesu  $AR(p)$  ve tvaru lineárního procesu (1) speciálně plyne, že

$$(63) \quad \text{cov}(y_{t-1}, \varepsilon_t) = \text{cov}(y_{t-2}, \varepsilon_t) = \dots = \text{cov}(y_{t-p}, \varepsilon_t) = 0.$$

V případě stacionárního a invertibilního  $ARMA(p, q)$  modelu (vyjádřeného pro jednoduchost s nulovou střední hodnotou)

$$(41) \quad y_t = \phi_1 y_{t-1} + \phi_2 y_{t-2} + \dots + \phi_p y_{t-p} + \varepsilon_t + \theta_1 \varepsilon_{t-1} + \dots + \theta_q \varepsilon_{t-q}$$

se nejčastěji používají **NLLS – odhady** realizované pomocí některé z **metod Gauss-Newtonovy třídy**.

Příslušná **NLLS – odhadová procedura** zde spočívá v minimalizaci součtu čtverců

$$(64) \quad \min_{\phi_1, \dots, \phi_p, \theta_1, \dots, \theta_q} \sum_{t=p+1}^n (y_t - \phi_1 y_{t-1} - \dots - \phi_p y_{t-p} - \theta_1 \varepsilon_{t-1} - \dots - \theta_q \varepsilon_{t-q})^2, \text{ kde}$$

$$e_t(\phi_1, \dots, \phi_p, \theta_1, \dots, \theta_q) = y_t - \phi_1 y_{t-1} - \dots - \phi_p y_{t-p} - \theta_1 \varepsilon_{t-1} - \dots - \theta_q \varepsilon_{t-q}$$

pro  $t = p+1, p+2, \dots, n$  s vhodně zvolenými hodnotami  $\varepsilon_{p-1+1}, \varepsilon_{p-1+2}, \dots, \varepsilon_p$ .

**Odhad rozptylu bílého šumu**  $\sigma_\varepsilon^2$  se potom obvykle získá tak, že minimální hodnotu (64) vydělíme délkou řady  $n$ . Za předpokladu normality a při dost velkém  $n$  jsou odhadové výsledky velmi blízké ML-odhadu (podmíněnému volbou  $\varepsilon_{p-1+1}, \varepsilon_{p-1+2}, \dots, \varepsilon_p$ ) získanému maximalizací logaritmované **věrohodnostní funkce**

$$(65) \quad L(\phi_1, \dots, \theta_q) = -\frac{n-p}{2} \ln \left( \frac{1}{2\pi} \right) - \frac{n-p}{2} \ln \sigma^2 - \frac{1}{2\sigma^2} \sum_{t=p+1}^n (y_t - \phi_1 y_{t-1} - \dots - \phi_p y_{t-p} - \theta_1 \varepsilon_{t-1} - \dots - \theta_q \varepsilon_{t-q})^2$$

**Tabulka: Přibližné hodnoty směrodatných odchylek odhadnutých parametrů ve vybraných stacionárních a invertibilních modelech Boxovy-Jenkinsovy metodologie:**

$AR(1)$	$\sigma(\hat{\phi}_1) = \sqrt{\frac{1 - \hat{\phi}_1^2}{n}}$
$AR(2)$	$\sigma(\hat{\phi}_1) = \tau \sigma(\hat{\phi}_2) = \sqrt{\frac{1 - \hat{\phi}_2^2}{n}}$
$MA(1)$	$\sigma(\hat{\theta}_1) = \tau \sigma(\hat{\phi}_2) = \sqrt{\frac{1 - \hat{\theta}_1^2}{n}}$
$MA(2)$	$\sigma(\hat{\phi}_1) = \tau \sigma(\hat{\theta}_2) = \sqrt{\frac{1 - \hat{\theta}_2^2}{n}}$
$ARMA(1,1)$	$\sigma(\hat{\phi}_1) = \sqrt{\frac{(1 - \hat{\phi}_1^2)(1 + \hat{\phi}_1 \hat{\theta}_1)}{n(\hat{\phi}_1 + \hat{\theta}_1)^2}}$ $\sigma(\hat{\theta}_1) = \sqrt{\frac{(1 - \hat{\theta}_1^2)(1 + \hat{\phi}_1 \hat{\theta}_1)}{n(\hat{\phi}_1 + \hat{\theta}_1)^2}}$

<sup>3</sup> **Poznámka** výchozí (nelogaritmovaná) věrohodnostní funkce má tvar

$$L(\phi_1, \dots, \theta_q) = \prod_{t=1}^{n-p} \frac{1}{\sqrt{2\pi\sigma^2}} \cdot \exp \left\{ -\frac{1}{2\sigma^2} \sum_{t=p+1}^n e_t(\phi_1, \dots, \theta_q)^2 \right\}$$

## Diagnostika modelu

Diagnostika modelu je v rámci **Box-Jenkinsovy metodologie** velmi propracovaná. Spočívá v tom, že pomocí různých diagnostických/verifikačních nástrojů ověříme adekvátnost sestaveného modelu (tj. prověříme, zda je skutečně konformní s analyzovanými daty). Přitom obvykle musíme brát v úvahu několik aspektů:

### 1. kontrola stacionarity modelu.

Především zde kontrolujeme, zda odhadnutý model skutečně splňuje **podmínku stacionarity**, tj. zda kořeny jeho odhadnutého autoregresního polynomu leží vně jednotkového kruhu v komplexní rovině (resp. zda ekvivalentně jejich převrácené hodnoty, což jsou kořeny autoregresního polynomu zapsaného s opačným uspořádáním mocnin leží uvnitř takového kruhu). Je také možné řadu rozdělit do několika úseků a testovat shodnost odhadnutých úrovní, rozptylů a autokorelací (popř. momentů vyšších řádů, zejména šikmost mezi jednotlivými úseky).

Jiný postup (tzv. **impuls response**) spočívá v analýze toho, jako odezvu má v odhadnutém modelu impuls  $m$  (většinou standardizovaný na velikost jedno nebo vícenásobek směrodatné odchylky bílého šumu), který nastal v jediném časovém okamžiku nebo opakovaně od daného časového okamžiku a přirozeně určuje následné hodnoty procesu – odhadnutá ARMA struktura se převede do tvaru lineárního procesu (1) a od daného okamžiku se sem dosazuje **inovační proces** s jedinou nenulovou hodnotu v tomto okamžiku nebo **inovační proces** se stále stejnými nenulovými hodnotami od tohoto okamžiku. Je-li analyzovaná řada stacionární, měla by s rostoucí časovou vzdáleností od okamžiku impulsů:

- (1) odezva pro jediný impuls postupně odeznít až na nulovou hodnotu
- (2) odezva pro opakovaný impuls se stabilizovat na určité (nenulové) úrovni.

### 2. kontrola struktury ARMA procesu

Rozumí se jí především **shoda korelační struktury odhadnuté z dat** (tj. **autokorelační a parciální autokorelační funkce**) s korelační strukturou vypočtenou z odhadnutého modelu, který ověříme. Jiná kontrola struktury modelu souvisí s testováním nekorelovanosti pro vypočtený bílý šum pomocí **Q-testů**.